28 | 模型训练（下）：协同过滤与频繁项集算法详解

2021-11-15 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 14:09 大小 12.97M

你好，我是吴磊。

如果你平时爱刷抖音，或者热衷看电影，不知道有没有过这样的体验：这类影视 App 你用得越久，它就好像会读心术一样，总能给你推荐对胃口的内容。其实这种迎合用户喜好的推荐，离不开机器学习中的推荐算法。

领资料

今天是咱们模型训练的最后一讲，在今天这一讲，我们就结合两个有趣的电影推荐场景，为你讲解 Spark MLlib 支持的协同过滤与频繁项集算法。与上一讲一样，咱们还是先来吐出下面这张“全景图”，方便你对学过和即将要学的知识做到心中有数。

Spark MLlib支持的模型算法

电影推荐场景

今天这一讲，咱们结合 Kaggle 竞赛中的 MovieLens 数据集，使用不同算法来构建简易的电影推荐引擎。尽管 MovieLens 数据集包含了多个文件，但课程中主要用到的，是 ratings.csv 这个文件。文件中的每条数据条目，记录的都是用户对于电影的打分，如下表所示。

userId	movieId	rating
1	151	4
1	1261	3.5
1	3030	3

极客时间

ratings.csv样本示例

其中第一列 userId 为用户 ID，movieId 表示电影 ID，而 rating 就是用户对于电影的评分。像这样，同时存有用户与物品（电影）信息的二维表，我们把它们统称为“交互矩阵”，或是“共现矩阵”。你可能会疑惑，通过这么一份简单的二维表，我们能干些什么呢？

可别小瞧这份数据，与合适的模型算法搭配在一起，我就能根据它们构建初具模样的推荐引擎。在 Spark MLlib 框架下，至少有两种模型算法可以做到这一点，一个是协同过滤（Collaborative Filtering），另一个是频繁项集（Frequency Patterns）。其中，前者天生就是用来做推荐用的，而后者是一种常规的非监督学习算法，你可以结合数据特点，把这个算法灵活运用于推荐场景。

协同过滤

我们先说协同过滤，从字面上来说，“过滤”是目的，而“协同”是方式、方法。简单地说，协同过滤的目标，就是从物品集合（比如完整的电影候选集）中，“过滤”出那些用户可能感兴趣的物品子集。而“协同”，它指的是，利用群体行为（全部用户与全部物品的交互历史）来实现过滤。

这样说有些绕，实际上，协同过滤的核心思想很简单，就是“**相似的人倾向于喜好相似的物品集**”。

交互矩阵看上去简单，但其中隐含着大量的相似性信息，只要利用合适的模型算法，我们就能挖掘出用户与用户之间的相似性、物品与物品之间的相似性，以及用户与物品之间的

相似性。一旦这些相似性可以被量化，我们自然就可以基于相似性去做推荐了。思路是不是很简单？

那么问题来了，这些相似性，该怎么量化呢？答案是：矩阵分解。

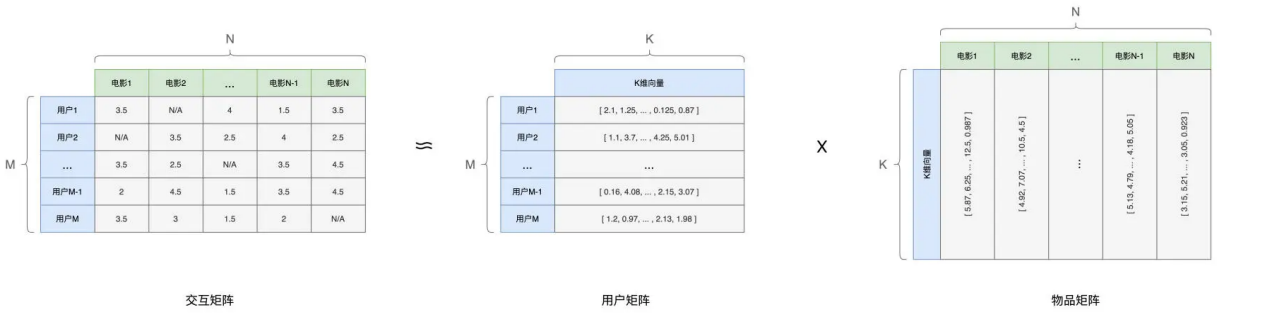

交互矩阵、用户矩阵与物品矩阵

在数学上，给定维度为（M，N）的交互矩阵 C，我们可以把它分解为两个矩阵 U 与 I 的乘积。其中，我们可以把 U 称作“用户矩阵”，它的维度为（M，K）；而 I 可以看作是“物品矩阵”，它的维度是（K，N）。

在用户矩阵与物品矩阵中，K 是超参数，它是由开发者人为设定的。不难发现，对于用户矩阵 U 中的每一行， 都可以看作是用户的 Embedding，也即刻画用户的特征向量。同理，物品矩阵中的每一列，也都可以看作是物品的 Embedding，也即刻画物品的特征向量。

正所谓，万物皆可 Embedding。对于任何事物，一旦它们被映射到同一个向量空间，我们就可以使用欧氏距离或是余弦夹角等方法，来计算他们向量之间的相似度，从而实现上述各种相似性（用户与用户、物品与物品、用户与物品）的量化。

基于相似度计算，我们就可以翻着花样地去实现各式各样的推荐。比方说，对于用户 A 来说，首先搜索与他 / 她最相似的前 5 个用户，然后把这些用户喜欢过的物品（电影）推荐给用户 A，这样的推荐方式，又叫基于用户相似度的推荐。

再比如，对于用户 A 喜欢过的物品，我们搜索与这些物品最相似的前 5 个物品，然后把这些搜索到的物品，再推荐给用户 A，这叫做基于物品相似度的推荐。

甚至，在一些情况下，我们还可以直接计算用户 A 与所有物品之间的相似度，然后把排名靠前的 5 个物品，直接推荐给用户 A。

基于上述逻辑，我们还可以反其道而行之，从物品的视角出发，给物品（电影）推荐用户。不难发现，一旦完成 Embedding 的转换过程，我们就可以根据相似度计算来灵活地设计推荐系统。

那么，接下来的问题是，在 Spark MLlib 的框架下，我们具体要怎么做，才能从原始的互动矩阵，获得分解之后的用户矩阵、物品矩阵，进而获取到用户与物品的 Embedding，并最终设计出简易的推荐引擎呢？

按照惯例，我们还是先上代码，用代码来演示这个过程。

复制代码

```
import org.apache.spark.sql.DataFrame

// rootPath表示数据集根目录
val rootPath: String = _
val filePath: String = s"${rootPath}/ratings.csv"

var data: DataFrame = spark.read.format("csv").option("header", true).load(fil

// 类型转换
import org.apache.spark.sql.types.IntegerType
import org.apache.spark.sql.types.FloatType

// 把ID类字段转换为整型，把Rating转换为Float类型
data = data.withColumn(s"userIdInt",col("userId").cast(IntegerType)).drop("use
data = data.withColumn(s"movieIdInt",col("movieId").cast(IntegerType)).drop("m
data = data.withColumn(s"ratingFloat",col("rating").cast(IntegerType)).drop("r

// 切割训练与验证数据集
val Array(trainingData, testData) = data.randomSplit(Array(0.8, 0.2))
```

第一步，还是准备训练样本，我们从 ratings.csv 创建 DataFrame，然后对相应字段做类型转换，以备后面使用。第二步，我们定义并拟合模型，完成协同过滤中的矩阵分解。

复制代码

```
import org.apache.spark.ml.recommendation.ALS

// 基于ALS（Alternative Least Squares，交替最小二乘）构建模型，完成矩阵分解
```

```
val als = new ALS()
.setUserCol("userIdInt")
.setItemCol("movieIdInt")
.setRatingCol("ratingFloat")
.setMaxIter(20)

val alsModel = als.fit(trainingData)
```

值得一提的是，在 Spark MLlib 的框架下，对于协同过滤的实现，Spark 并没有采用解析解的方式（数学上严格的矩阵分解），而是用了一种近似的方式来去近似矩阵分解。这种方式，就是 ALS（Alternative Least Squares，交替最小二乘）。

具体来说，给定交互矩阵 C，对于用户矩阵 U 与物品矩阵 I，Spark 先给 U 设定一个初始值，然后假设 U 是不变的，在这种情况下，Spark 把物品矩阵 I 的优化，转化为回归问题，不停地去拟合 I，直到收敛。然后，固定住物品矩阵 I，再用回归的思路去优化用户矩阵 U，直至收敛。如此反复交替数次，U 和 I 都逐渐收敛到最优解，Spark 即宣告训练过程结束。

因为 Spark 把矩阵分解转化成了回归问题，所以我们可以用回归相关的度量指标来衡量 ALS 模型的训练效果，如下所示。

复制代码

```
import org.apache.spark.ml.evaluation.RegressionEvaluator

val evaluator = new RegressionEvaluator()
// 设定度量指标为RMSE
.setMetricName("rmse")
.setLabelCol("ratingFloat")
.setPredictionCol("prediction")

val predictions = alsModel.transform(trainingData)
// 计算RMSE
val rmse = evaluator.evaluate(predictions)
```

验证过模型效果之后，接下来，我们就可以放心地从模型当中，去获取训练好的用户矩阵 U 和物品矩阵 I。这两个矩阵中，保存的正是用户 Embedding 与物品 Embedding。

复制代码

```
alsModel.userFactors

```

```
// org.apache.spark.sql.DataFrame = [id: int, features: array<float>]

alsModel.userFactors.show(1)
/** 结果打印
+---+--------------------+
| id| features|
+---+--------------------+
| 10|[0.53652495, -1.0...|
+---+--------------------+
*/

alsModel.itemFactors
// org.apache.spark.sql.DataFrame = [id: int, features: array<float>]

alsModel.itemFactors.show(1)
/** 结果打印
+---+--------------------+
| id| features|
+---+--------------------+
| 10|[1.1281404, -0.59...|
+---+--------------------+
*/
```

就像我们之前说的，有了用户与物品的 Embedding，我们就可以灵活地设计推荐引擎。如果我们想偷懒的话，还可以利用 Spark MLlib 提供的 API 来做推荐。具体来说，我们可以通过调用 ALS Model 的相关方法，来实现向用户推荐物品，或是向物品推荐用户，如下所示。

复制代码

```
// 为所有用户推荐10部电影
val userRecs = alsModel.recommendForAllUsers(10)

// 为每部电影推荐10个用户
val movieRecs = alsModel.recommendForAllItems(10)

// 为指定用户推荐10部电影
val users = data.select(als.getUserCol).distinct().limit(3)
val userSubsetRecs = alsModel.recommendForUserSubset(users, 10)

// 为指定电影推荐10个用户
val movies = data.select(als.getItemCol).distinct().limit(3)
val movieSubSetRecs = alsModel.recommendForItemSubset(movies, 10)
```

好啦，到此为止，我们介绍了协同过滤的核心思想与工作原理，并使用 Spark MLlib 提供的 ALS 算法，实现了一个简单的电影推荐引擎。接下来，我们再来想一想，还有没有其他

的思路来打造一个不一样的推荐引擎。

频繁项集

频繁项集（Frequency Patterns），是一种经典的数据挖掘算法，我们可以把它归类到非监督学习的范畴。频繁项集可以挖掘数据集中那些经常“成群结队”出现的数据项，并尝试在它们之间建立关联规则（Association Rules），从而为决策提供支持。

举例来说，基于对上百万条交易记录的统计分析，蔬果超市发现（“葱”，“姜”，“蒜”）这三种食材经常一起出现。换句话说，购买了“葱”、“姜”的人，往往也会再买上几头蒜，或是买了大葱的人，结账前还会再把姜、蒜也捎上。

在这个购物篮的例子中，（“葱”，“姜”，“蒜”）就是频繁项（Frequency Itemset），也即经常一起共现的数据项集合。而像（“葱”、“姜”->“蒜”）和（“葱”->“姜”、“蒜”）这样的关联关系，就叫做关联规则。

不难发现，基于频繁项与关联规则，我们能够提供简单的推荐能力。以刚刚的（“葱”，“姜”，“蒜”）为例，对于那些手中提着大葱、准备结账的人，精明的导购员完全可以向他 / 她推荐超市新上的河北白皮蒜或是山东大生姜。

回到电影推荐的场景，我们同样可以基于历史，挖掘出频繁项和关联规则。比方说，电影（“八佰”、“金刚川”、“长津湖”）是频繁项，而（“八佰”、“金刚川”->“长津湖”）之间存在着关联关系。那么，对于看过“八佰”和“金刚川”的人，我们更倾向于判断他 / 她大概率也会喜欢“长津湖”，进而把这部电影推荐给他 / 她。

那么，基于 MovieLens 数据集，在 Spark MLlib 的开发框架下，我们该如何挖掘其中的频繁项与关联规则呢？

首先第一步，是数据准备。在蔬果超市的例子中，超市需要以交易为单位，收集顾客曾经一起购买过的各种蔬果。为了在 MovieLens 数据集上计算频繁项集，我们也需要以用户为粒度，收集同一个用户曾经看过的所有电影集合，如下图所示。

userId	movieId	rating
1	151	4
1	1261	3.5
1	3030	3

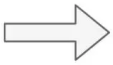

userId	movies
1	[151, 1261, 3030]

极客时间

数据转换示意图

要完成这样的转换，我们只需要一行代码即可搞定。

复制代码

```
// data是从ratings.csv创建的DataFrame
val movies: DataFrame = data
// 按照用户分组
.groupBy("userId")
// 收集该用户看过的所有电影，把新的集合列命名为movieSeq
.agg(collect_list("movieId").alias("movieSeq"))
// 只保留movieSeq这一列，去掉其他列
.select("movieSeq")

// movies: org.apache.spark.sql.DataFrame = [movieSeq: array<string>]

movies.show(1)
/** 结果打印
+--------------------+
| movieSeq|
+--------------------+
|[151, 172, 236, 2...|
+--------------------+
*/
```

数据准备好之后，接下来，我们就可以借助 Spark MLlib 框架来完成频繁项集的计算。

复制代码

```
import org.apache.spark.ml.fpm.FPGrowth

val fpGrowth = new FPGrowth()
// 指定输入列
.setItemsCol("movieSeq")
// 超参数，频繁项最小支持系数
.setMinSupport(0.1)
```

```
// 超参数，关联规则最小信心系数
.setMinConfidence(0.1)

val model = fpGrowth.fit(movies)
```

可以看到，定义并拟合频繁项集模型，还是比较简单的，用法上与其他模型算法大同小异。不过，这里有两个超参数需要特别关注，一个是由 setMinSupport 设置的最小支持系数，另一个是由 setMinConfidence 指定的最小信心系数。

最小支持系数，它用来设定频繁项的“选拔阈值”，这里我们把它设置为 0.1。这是什么意思呢？

举例来说，在 MovieLens 数据集中，总共有 7120 个用户，相应地，movies 这个 DataFrame 中，就有 7120 条电影集合数据。对于（“八佰”、“金刚川”、“长津湖”）这个组合来说，当且仅当它出现的次数大于 712（7120 * 0.1），这个组合才会被算法判定为频繁项。换句话说，**最小支持系数越高，算法挖掘出的频繁项越少、越可靠，反之越多。**

相应地，最小信心系数，是用来约束关联规则的，例子中的取值也是 0.1。我们再来举例说明，假设在 7120 条电影集合数据中，（“八佰”、“金刚川”）这对组合一起出现过 1000 次，那么要想（“八佰”、“金刚川”-> “长津湖”）这条关联规则成立，则（“八佰”、“金刚川”、“长津湖”）这个组合必须至少出现过 100 次（1000 * 0.1）。同理，**最小信心系数越高，算法挖掘出的关联规则越少、越可靠，反之越多。**

模型训练好之后，我们就可以从中获取经常出现的频繁项与关联规则，如下所示。

复制代码

```
model.freqItemsets.show(1)
/** 结果打印
+--------------------+----+
| items|freq|
+--------------------+----+
|[318, 593, 356, 296]|1465|
+--------------------+----+
*/

model.associationRules.show(1)
/** 结果打印
+--------------------+----------+------------------+
| antecedent|consequent| confidence|
```

```
+--------------------+----------+------------------+
|[592, 780, 480, 593]| [296]|0.8910463861920173|
+--------------------+----------+------------------+
*/
```

基于关联规则，我们就可以提供初步的推荐功能。比方说，对于看过（592、780、480、593）这四部电影的用户，我们可以把 ID 为 296 的电影推荐给他 / 她。

重点回顾

好啦，到此为止，模型训练的上、中、下三讲，我们就全部讲完啦！这三讲的内容较多，涉及的算法也很多，为了让你对他们有一个整体的把握，我把这些算法的分类、原理、特点与适用场景，都整理到了如下的表格中，供你随时回顾。

算法分类	算法子分类	算法	原理与特点	适用场景
监督学习	回归、分类	决策树	决策树的构建过程，与人类的思考过程及其相似。通过遍历每一个特征，并考察每个特征的“提纯”能力，来构建决策树	既可以用于解决分类问题，也可以解决回归问题
	选取所有数值字段	GBDT	核心思想是“站在前人的肩膀上看得更远”，每一棵树的训练，都是基于前一棵树拟合的样本残差，从而使得预测值不断地逼近真实值	
	特征选择	随机森林	设计思想是“三个臭皮匠、赛过诸葛亮”。通过在多棵树上随机选取训练样本与特征，随机森林将多个简单模型集成在一起，用投票的方式共同来决定最终的预测结果	
	归一化	ALS	“过滤”是目的，而“协同”是方法。协同过滤的目标，就是从物品集合（比如完整的电影候选集）中，“过滤”出那些用户可能感兴趣的物品子集。而“协同”，指的是利用群体行为（全部用户与全部物品的交互历史）来实现过滤的过程	用户、物品推荐；构建用户、物品Embedding，Embedding可当作生成特征，来补充已有算法的特征工程
非监督学习	聚类	K-means	K-means的计算主要依赖向量之间的相对距离，将相似向量聚集到一起	一方面可以直接用于划分“人群”、“种群”，另一方面可以拿来当做生成特征，参与到监督学习的训练中
	频繁项集	FPGrowth	挖掘数据集中那些经常“成群结队”出现的数据项，并尝试在他们之间建立关联规则，从而为决策提供支持	可用于挖掘频繁项与物品之间的关联关系，用于推荐

极客时间

不难发现，机器学习的场景众多，不同的场景下，又有多种不同的算法供我们选择。掌握这些算法的原理与特性，有利于我们高效地进行模型选型与模型训练，从而去解决不同场景下的特定问题。

对于算法的调优与应用，还需要你结合日常的实践去进一步验证、巩固，也欢迎你在留言区分享你的心得与体会，让我们一起加油！

每课一练

对于本讲介绍的两种推荐思路（协同过滤与频繁项集），你能说说他们各自的优劣势吗？

你有什么学习收获或者疑问，都可以跟我交流，咱们留言区见。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 27 | 模型训练（中）：回归、分类和聚类算法详解

下一篇 29 | Spark MLlib Pipeline：高效开发机器学习应用

更多学习推荐

精选留言 (1)

写留言

崔小豪

2021-11-17

协同过滤算法本身其实对于推荐什么物品是一点都不关心的，所有的推荐机制都是基于用户对物品的行为来制定的, 优点基于用户行为，因此对推荐内容无需先验知识；只需要用户和商品的关联矩阵即可，结构简单；在用户行为丰富的情况下，效果好。 当然如此一来，缺点也非常明显：需要大量的显性/隐形的用户行为数据，有冷启动问题；需要通过完全相同的商品关联，相似的不行 aka 同义词问题；在数据稀疏的情况下易受影响。...

展开

作者回复: 老弟总结得很到位，赞~